

پیش‌بینی نوسانات ماهانه سطح آب دریاچه ارومیه با استفاده از مدل هوش مصنوعی مرکب نظارت‌شده

رحیم برزگر^۱، اصغر اصغری مقدم^{۲*}، الهام فیجانی^۳

تاریخ دریافت: ۹۶/۰۷/۰۱

تاریخ پذیرش: ۹۷/۰۹/۲۵

۱- دانشجوی دکتری هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

۲- استاد گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز

۳- استادیار دانشکده زمین‌شناسی، پردیس علوم، دانشگاه تهران

* مسئول مکاتبات، پست الکترونیکی: Moghaddam@tabrizu.ac.ir

چکیده

در سال‌های اخیر کاهش سطح آب دریاچه ارومیه سبب ایجاد بحران آبی و زیست‌محیطی در منطقه گردیده است. بنابراین ضروری است که مدیریت و برنامه‌ریزی صحیح و قابل‌اعتماد در این زمینه صورت گیرد که لازمه آن مدل‌سازی سطح آب دریاچه برای آینده می‌باشد. در این تحقیق از روش‌های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) برای پیش‌بینی سطح آب یک [h (t+1)]، دو [h (t+2)] و سه [h (t+3)] ماه آینده دریاچه ارومیه استفاده گردید و در نهایت از یک مدل هوش مصنوعی مرکب نظارت شده (SCMAI) برای رسیدن به یک عملکرد بهتر از مدل‌های منفرد به‌کار گرفته شده، استفاده شد. برای مدل‌سازی، اطلاعات سطح آب ماه جاری [h (t)] و یازده ماه گذشته [h (t-1), ..., h (t-11)] به‌عنوان ورودی و سطح آب یک، دو و سه ماه آینده به‌عنوان خروجی مدل‌ها در نظر گرفته شدند. داده‌ها به دو دسته داده‌های آموزش/اعتبارسنجی (۹۰ درصد کل داده‌ها) و داده‌های آزمایش (۱۰ درصد کل داده‌ها) تقسیم‌بندی گردیدند و پس از مدل‌سازی، عملکرد مدل‌ها بر اساس پارامترهای ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و میانگین مطلق خطا (MAE) ارزیابی شدند. نتایج نشان دادند که مدل‌های بردار پشتیبان عملکرد بهتری نسبت به مدل‌های شبکه عصبی مصنوعی و عصبی-فازی دارند. مدل هوش مصنوعی مرکب نظارت شده به‌منظور ترکیب نتایج مدل‌های مختلف به‌کار گرفته شد و نشان داد که مدل‌های هوش مصنوعی مرکب نظارت شده قادرند کارایی مدل‌های منفرد هوش مصنوعی را بهبود بخشند. نتایج معیارهای عملکرد مدل هوش مصنوعی مرکب نظارت شده بیان می‌کند که مدل‌سازی یک ماه آینده سطح آب با مقادیر R^2 ، RMSE و MAE به‌ترتیب برابر با ۰/۹۸۹۶، ۰/۰۵۴۷ متر و ۰/۰۴۲۱ متر در مقایسه با مدل بردار پشتیبان عملکرد بهتری دارد که این عملکرد برای پیش‌بینی‌های دو و سه ماه آینده سطح آب دریاچه نیز صادق می‌باشد.

واژه‌های کلیدی: پیش‌بینی، سطح آب، هوش مصنوعی مرکب نظارت‌شده، دریاچه ارومیه، ماشین بردار پشتیبان

Forecasting Monthly Water Level Fluctuations of Lake Urmia Using Supervised Committee Machine Artificial Intelligence Model

R Barzegar¹, A Asghari Moghaddam^{2*}, E Fijani³

¹Ph.D student of Hydrogeology, Dept. of Earth Sciences, Faculty of Natural Sciences, Univ. of Tabriz, Iran

²Prof., Dept. of Earth Sciences, Faculty of Natural Sciences, Univ. of Tabriz, Iran

³Assist. Prof., School of Geology, University College of Science, University of Tehran, Tehran, Iran

* Corresponding Author, Email: Moghaddam@tabrizu.ac.ir

Abstract

In recent years, declining the water level of Lake Urmia has caused water and environmental crisis in the area. Therefore, it is urgent to carry out an accurate and reliable management and planning which requires modeling the lake's water level for the future. In this research, the artificial neural network (ANN), adaptive neuro fuzzy inference system (ANFIS) and support vector machine (SVM) models were used to forecast the Lake Urmia water level fluctuations for one, two and three months ahead forecast horizons and finally, a supervised committee machine artificial intelligence (SCMAI) model was used to obtain a better performance than the used individual models. To develop the models, the current month $[h(t)]$ and eleven months water level lags $[h(t-1), h(t-11)]$ were introduced as input variables to forecast one, two and three steps ahead water levels. The datasets were divided into two subsets of training/validation (90%) and testing (10%). The performances of the models were evaluated based on the coefficient of determination (R^2), the root mean square error (RMSE) and the mean absolute error (MAE). The results showed that the SVM models had better performance than the ANN and ANFIS models. The SCMAI model was applied to combine the used models' outputs and illustrated that the SCMAI models are able to improve the performance of the individual artificial intelligence models. The results of the performance criteria for SCMAI model indicated that the one-month step ahead water level modeling with R^2 , RMSE and MAE equal to 0.9896, 0.0547 m and 0.0421 m, respectively outperformed in comparison with SVM model which this performance is reliable for the two- and three-months step ahead lake's water level.

Keywords: Forecasting, Supervised committee machine artificial intelligence, Support vector machine, Lake Urmia, Water level

مقدمه

مدلسازی نوسانات سطح آب دریاچه‌ها در برنامه‌ریزی، طراحی، ساخت و راه‌اندازی سازه‌های هیدرولیکی واقع در امتداد دریاچه‌ها، مدیریت آب شیرین برای اهداف تأمین آب، آبیاری، نوسانات جزر و مدی و همچنین عملیات کانال زهکشی ضروری است (ثانی خانی و همکاران ۲۰۱۵). مدل‌های پیشرفته پیش‌بینی سطح آب دریاچه می‌تواند با استفاده از متغیرهای هیدرولوژیکی و آب و هواشناسی مانند بارش، رواناب، درجه حرارت و تبخیر توسعه یابد. با این وجود، زمانی که کاربر به‌عنوان یک تصمیم‌گیرنده می‌باشد، توسعه مدلی که نوسانات آینده سطح آب دریاچه را بر پایه اطلاعات سطح آب

روند نزولی سطح آب دریاچه ارومیه به عنوان مهم‌ترین دریاچه ایران، در سال‌های اخیر توجه بسیاری را به خود جلب کرده است. از جمله مهم‌ترین عوامل مؤثر در روند نزولی سطح آب دریاچه می‌توان به توسعه نامتوازن بخش کشاورزی حوضه آبریز دریاچه و برداشت بیش از حد از منابع آب تجدیدپذیر این حوضه و جلوگیری از ورود منابع آب سطحی به دریاچه اشاره کرد. همچنین استمرار و تشدید دوره‌های خشکسالی و نوسانات اقلیمی (کاهش متوسط بارش و رواناب در سطح حوضه) دیگر عامل خشکی این دریاچه محسوب می‌شود.

مقایسه با مدل‌های GEP و ANN از نظر تعمیم و دقت پیش بینی نتایج بهتری دارد. شیری و همکاران (۲۰۱۶) از مدل ماشین یادگیری افراطی برای پیش‌بینی سطح آب روزانه دریاچه ارومیه بهره گرفتند. آنان به این نتیجه رسیدند که عملکرد مدل ELM برای پیش‌بینی سطح آب دریاچه در مقایسه با ANN و GP بهتر است.

در پیش‌بینی متغیرها عموماً بیش از یک مدل هوش مصنوعی می‌تواند به کار گرفته شود که ممکن است نتایج مشابهی به دست دهند. هر کدام از مدل‌ها دارای عدم قطعیت و مزایای مربوط به خود هستند. بنابراین مدل‌های چندگانه^{۱۲} از جمله مدل‌های هوش مصنوعی مرکب^{۱۳} (CMAI) برای پیش‌بینی چنین متغیرهایی گسترش یافته‌اند (نفتالی و همکاران ۱۹۹۷، کخدایی ایلخچی و همکاران ۲۰۰۹، برزگر و اصغری مقدم ۲۰۱۶، برزگر و همکاران ۲۰۱۶c). پایه تئوری این روش استفاده ترکیبی از نتایج هر یک از روش‌ها برای رسیدن به یک نتیجه کلی و بهتر است. به این ترتیب، می‌توان از برتری انفرادی هر کدام از مدل‌ها برای رسیدن به یک مدل ترکیبی بهتر بهره گرفت. مطالعات قبلی از روش هوش مصنوعی مرکب نظارت‌شده^{۱۴} به منظور ترکیب مدل‌های مختلف هوش مصنوعی استفاده کرده‌اند. برای مثال برزگر و همکاران (۲۰۱۶c) برای ترکیب روش‌های مختلف هوش مصنوعی (شبکه عصبی مصنوعی، فازی و عصبی-فازی) به منظور بهینه‌سازی مدل دراستیک در ارزیابی آسیب‌پذیری آبخوان دشت تبریز، روش هوش مصنوعی مرکب نظارت شده را به کار گرفتند. ندیری و همکاران (۱۳۹۳) برای تخمین قابلیت انتقال آبخوان دشت تسوج به منظور ترکیب روش‌های مختلف مدل فازی

گذشته پیش‌بینی کند، مقرون به صرفه‌تر است (شن و همکاران ۲۰۰۰، ثانی‌خانی و همکاران ۲۰۱۵). مدل‌های هوش مصنوعی که در مدل‌سازی پدیده‌های غیر خطی پیچیده در سیستم‌های هیدرولوژی و منابع آب استفاده می‌شوند، به تازگی گسترش در دامنه کاربرد آنها دیده می‌شود. اخیراً تعدادی از این مدل‌های هوش مصنوعی شامل شبکه‌های عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی، برنامه ریزی بیان ژن^۱ (GEP)، ماشین بردار پشتیبان^۲ (SVM) و ماشین یادگیری افراطی^۳ (ELM) برای مدل‌سازی و پیش‌بینی نوسانات سطح آب دریاچه ارومیه به کار برده شده‌اند. طالبی‌زاده و مریدنژاد (۲۰۱۱) دریافتند که مدل سیستم استنتاجی فازی-عصبی تطبیقی^۴ (ANFIS) در مقایسه با مدل شبکه عصبی مصنوعی^۵ (ANN) کارایی بهتری در پیش‌بینی سطح آب دریاچه ارومیه دارد. کریمی و همکاران (۲۰۱۲) دریافتند که مدل‌های هوش مصنوعی همچون GEP و ANFIS عملکرد بهتری نسبت به مدل‌های مرسوم همچون مدل الگوی خودرگرسیون میانگین متحرک^۶ (ARMA) دارد. کاکاحاجی و همکاران (۲۰۱۳) به این نتیجه رسیدند که مدل‌های هوش مصنوعی مانند شبکه پرسپترون چند لایه^۷ (MLP) و نروفازی خطی محلی^۸ (LLNF) در مدل‌سازی سطح آب دریاچه ارومیه نتایج بهتری نسبت به مدل‌های آماری خطی همچون خودرگرسیون با متغیر برونزا^۹ (ARX) و باکس-جنکینس^{۱۰} (BJ) ارائه می‌دهند. کیشی و همکاران (۲۰۱۵) از مدل کرم شب تاب-ماشین بردار پشتیبان^{۱۱} (SVM-FA) برای پیش‌بینی سطح آب یک روز آینده دریاچه ارومیه استفاده کردند. آنها نشان دادند که این مدل در

8. Locally linear neuro fuzzy
9. Autoregressive with exogenous input
10. Box-Jenkins
11. Support vector machine- firefly algorithm
12. Multi-model
13. Committee machine artificial intelligence
14. Supervised committee machine artificial intelligence

1. Gene expression programming
2. Support vector machine
3. Extreme learning machine
4. Adaptive neuro fuzzy inference system
5. Artificial neural network
6. Autoregressive moving average
7. Multi-layer perceptron

است. این دریاچه با موقعیت جغرافیایی ۳۵ درجه و ۴۰ دقیقه تا ۳۸ درجه و ۲۹ دقیقه عرض شمالی و نصف‌النهار ۴۴ درجه و ۱۳ دقیقه تا ۴۷ درجه و ۵۳ دقیقه طول شرقی، بزرگ‌ترین دریاچه داخلی ایران و دومین دریاچه بزرگ آب‌شور دنیا می‌باشد. وسعت حوضه آبریز دریاچه ارومیه در حدود ۵۲۳۵۵ کیلومتر مربع می‌باشد که از این مقدار حدود ۵۸۲۲ کیلومتر مربع وسعت خود دریاچه است که مستقیماً با ارتفاع آب دریاچه ارتباط داشته و با افزایش یا کاهش حجم آب آن تغییر پیدا می‌کند. این دریاچه نقش اجتماعی-اقتصادی و اکولوژیکی مهمی در شمال‌غرب ایران دارد. با این وجود، سطح آب دریاچه در سال‌های اخیر کاهش یافته و یک چهارم دریاچه به شوره‌زار تبدیل شده است. به دلیل توپوگرافی خاص و شوری بالای آب دریاچه، آب آن برای مصارف مختلف مناسب نمی‌باشد.

در این مطالعه از اطلاعات سطح آب ماهانه دریاچه ارومیه برای یک دوره زمانی ۶۶ ساله (آبان ماه سال ۱۳۴۵ تا شهریور ماه سال ۱۳۹۱) استفاده گردید. جدول ۱ خصوصیات آماری داده‌های ماهانه سطح آب دریاچه ارومیه برای این دوره زمانی را نشان می‌دهد. مقادیر بیشینه و کمینه سطح آب دریاچه در این دوره زمانی به ترتیب ۱۲۷۸/۳۸ و ۱۲۷۰/۶۳ متر (با میانگین ۱۲۷۵/۲۳ متر) می‌باشند. شکل ۱ نمودار سری زمانی داده‌های سطح آب ماهانه دریاچه را نشان می‌دهد.

جدول ۱- خصوصیات آماری داده‌های ماهانه سطح آب دریاچه ارومیه.

کمینه	میانگین	میانه	بیشینه	انحراف معیار
۱۲۷۰/۶۳	۱۲۷۵/۲۳	۱۲۷۵/۷۲	۱۲۷۸/۳۸	۱/۷۰

سطح آب دریاچه ارومیه (m)


(ساجنو، ممدانی و لارسن) از این روش استفاده کردند. ندری و همکاران (۱۳۹۵) از روش ترکیب غیرخطی نظارت‌شده مدل‌های هوش مصنوعی شامل شبکه‌های عصبی پیشرو^{۱۵} (FFNN)، شبکه‌های عصبی برگشتی^{۱۶} (RNN) و برنامه‌نویسی بیان ژن به منظور پیش‌بینی سطح آب زیرزمینی آبخوان دشت بستان آباد بهره گرفتند.

در سال‌های اخیر کاهش سطح آب دریاچه ارومیه سبب ایجاد بحران آبی و زیست محیطی در منطقه گردیده است. بنابراین ضروری است که مدیریت و برنامه‌ریزی صحیح و قابل‌اعتماد در این زمینه صورت گیرد که لازمه آن مدل‌سازی سطح آب دریاچه برای آینده می‌باشد. در این تحقیق از روش‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و ماشین بردار پشتیبان برای پیش‌بینی سطح آب یک [h (t+1)]، دو [h (t+2)] و سه [h (t+3)] ماه آینده دریاچه ارومیه استفاده گردید و در نهایت از یک مدل هوش مصنوعی مرکب نظارت‌شده برای رسیدن به یک عملکرد بهتر نسبت به مدل‌های منفرد به‌کار گرفته شده، استفاده شد.

مواد و روش‌ها

مشخصات منطقه مطالعاتی و اطلاعات مورد استفاده

دریاچه ارومیه در شمال‌غرب ایران بین استان-های آذربایجان شرقی و آذربایجان غربی قرار گرفته



شکل ۱- نمودار سری زمانی داده‌های ماهانه سطح آب دریاچه ارومیه (آبان ماه سال ۱۳۴۵ تا شهریور ماه سال ۱۳۹۱).

حالی که از نوسانات فصلی بیش از یک سال به دلیل دستیابی به یک مدل با صرفه چشم‌پوشی گردید. با چشم‌پوشی از نوسانات فصلی بیش از یک سال، با توجه به شکل ۲ ج مشاهده می‌شود که بیشتر مقدار نوسانات فصلی در ماه دوازدهم سال (برای مثال $11/36 = 0/88$) می‌باشد. بنابراین، برای مدل‌سازی در این مطالعه همبستگی بین دوازده ماه از سال در نظر گرفته شد و نوسانات سطح آب ماه جاری $[h(t)]$ و یازده ماه قبل $[h(t-1), \dots, h(t-11)]$ به عنوان ورودی مدل‌ها برای پیش‌بینی سطح آب یک $[h(t+1)]$ ، دو $[h(t+2)]$ و سه $[h(t+3)]$ ماه آینده دریاچه ارومیه به‌کار گرفته شد. انتخاب سه ماه آینده برای پیش‌بینی نیز به دلیل نوسانات فصلی سطح آب دریاچه می‌باشد.

برای مدل‌سازی، اطلاعات سطح آب ماهانه به کار گرفته شده به دو دسته داده‌های آموزش/ اعتبارسنجی (۹۰ درصد کل داده‌ها) در بازه زمانی آذر ماه سال ۱۳۴۴ تا شهریور ماه سال ۱۳۸۵ و داده‌های آزمایش (۱۰ درصد کل داده‌ها) در بازه زمانی مهر ماه سال ۱۳۸۵ تا آذر ماه سال ۱۳۹۱ تقسیم‌بندی گردید. برای مدل‌سازی هوش مصنوعی، داده‌های ورودی و خروجی مدل‌ها با استفاده از رابطه ۱ بین صفر و یک نرمالیزه شد. در این روابط، X_N مقدار نرمالیزه شده متغیر X و X_{min} و X_{max} مقادیر بیشینه و کمینه متغیر X قبل از نرمالیزه کردن می‌باشند.

یکی از مهم‌ترین مراحل در استفاده از مدل‌های هوش مصنوعی، تعیین پارامترهای ورودی مدل می‌باشد. تحلیل وابسته به زمان داده‌های سطح آب دریاچه ارومیه (شکل ۲ الف) نشان می‌دهد که تابع خود همبستگی^{۱۷} (ACF) سطح آب دریاچه تمایل دارد که یک حافظه نامحدود داشته باشد که این امر با یافته‌های سالاس و همکاران (۱۹۸۰) و واحد دوست و همکاران (۲۰۱۶) منطبق است. آنان دریافتند که سطح آب در مخازن (برای مثال دریاچه‌ها) ادامه‌دار و متناوب می‌باشد. نمودار خودهمبستگی جزئی^{۱۸} (PACF) در شکل ۲ ب نشان می‌دهد که تأخیرهای ۱، ۲، ۱۲ و ۱۳ تأثیر به‌سزایی در نوسانات سطح آب دریاچه ارومیه دارند. به‌علاوه، طیف توان سطح آب ماهانه دریاچه ارومیه (شکل ۲ ج) نشان می‌دهد که چندین افزایش ناگهانی سطح آب به‌صورت بین سالیانه و چندساله وجود دارند که نشان‌دهنده بی-نظمی در سری زمانی سطح آب دریاچه ارومیه می‌باشد (خاتمی ۲۰۱۳). همان‌طور که در شکل ۲ الف و ج نشان داده شده است، نوسانات فصلی قوی که به نوسانات سالیانه نیز می‌رسد، وجود دارد. این نوسانات فصلی استفاده از تعداد زیادی از متغیرهای ورودی (سطح آب دریاچه) که قبلاً مشاهده شده است، را می‌طلبد (واحد دوست و همکاران ۲۰۱۶). در این مطالعه فقط نوسانات فصلی در داخل یک سال در نظر گرفته شد در

18. Partial auto-correlation function

17. Auto-correlation function

محاسبات از ورودی شبکه به سوی خروجی شبکه انجام می‌شود و سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد. در ابتدا، محاسبه خروجی به صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود (برزگر و اصغری مقدم ۲۰۱۶).

مدل‌های شبکه عصبی به کار گرفته شده در این مطالعه از نوع شبکه چند لایه پیشرو با الگوریتم پس-انتشار خطا و تکنیک یادگیری مارکوارت - لوبنبرگ^{۲۰} می-باشند. بنابراین، با استفاده از رابطه ۲ خواهیم داشت (برزگر و همکاران ۲۰۱۶b):




$$\hat{y}_k = f_o \left[\sum_{i=1}^{M_N} W_{kj} \cdot f_h \left(\sum_{i=1}^{N_N} W_{ji} X_i + W_{j0} \right) + W_{k0} \right] \quad [2]$$

در این رابطه X_i متغیرهای ورودی لایه ورودی، \hat{y}_k متغیرهای خروجی محاسباتی، f_h تابع انتقال لایه پنهان، f_o تابع انتقال برای نرون خروجی، N_N تعداد نرون‌های لایه ورودی، M_N تعداد نرون‌های لایه پنهان، W_{ji} وزن لایه پنهان که i^{th} نرون در لایه ورودی را به j^{th} نرون در لایه پنهان وصل می‌کند، W_{j0} بایاس j^{th} لایه پنهان، W_{kj} وزن لایه خروجی که j^{th} نرون در لایه پنهان را به k^{th} نرون در لایه خروجی وصل می‌کند و W_{k0} بایاس k^{th} نرون خروجی می‌باشند.

برای تمامی مدل‌های شبکه عصبی مصنوعی تابع انتقال از لایه اول به دوم تابع تانژانت هیپربولیک (TANSIG) و از لایه دوم به سوم تابع تبدیل خطی (PURELIN) در نظر گرفته شدند که اغلب بهترین نتایج را ارائه می‌دهند (برزگر و همکاران ۲۰۱۶a). تعداد گام‌ها^{۲۱} برای تمامی مدل‌ها ۱۰۰۰ در نظر گرفته شد. سپس با روش آزمون و خطا براساس رسیدن به بهترین عملکرد شبکه (کمترین خطا)، تعداد نرون‌های پنهان تعیین گردیدند.

مدل استنتاج فازی-عصبی تطبیقی

سیستم‌های استنتاج فازی-عصبی تطبیقی شامل شبکه‌های چند لایه‌ای می‌باشند و از الگوریتم‌های



شکل ۲- نمودار الف) خودهمبستگی (ACF)، ب) خودهمبستگی جزئی (PACF) و ج) طیف توان سطح آب ماهانه دریاچه ارومیه.

$$X_N = \frac{X - X_{min}}{X_{max} - X_{min}} \quad [1]$$

شبکه عصبی مصنوعی

شبکه پرسپترون چند لایه از شبکه‌های عصبی مصنوعی است که بر مبنای یک واحد محاسباتی به نام پرسپترون ساخته می‌شود. در طی آموزش شبکه MLP به کمک الگوریتم یادگیری پس‌انتشار خطا^{۱۹} (BP)، ابتدا

20. Levenberg-Marquardt
21. Epoch

19. Back propagation

که در آن، $(\alpha_i - \alpha_i^*)$ ضرایب لاگرانژ، $K(x, z)$ تابع کرنل و b_i بایاس می‌باشند.

سه فاکتور عملکرد یک رگرسیون ماشین بردار پشتیبان را تحت تأثیر قرار می‌دهند که عبارتند از: ثابت خطای غیرحساس (ϵ)، فاکتور تنظیم (C) و پارامتر کرنل (γ) می‌باشند (ابتهاج ۲۰۱۶). ϵ ثابت پهنای باندی را تعریف می‌کند که از خطا صرف‌نظر می‌شود و هر چقدر این ثابت کوچک‌تر شود، تعداد بردارهای پشتیبان تعیین شده توسط SVM افزایش می‌یابد. پارامتر C پیچیدگی سیستم را تنظیم می‌کند که توسط بردار وزن‌دهنده شده و خطاهای تخمینی اندازه‌گیری شده توسط ϵ مشخص می‌شود. انتخاب توابع کرنل و همچنین پارامترهای مدل، نقش مهمی را در عملکرد مدل بردار پشتیبان ایفا می‌کنند. در این تحقیق از تابع پایه شعاعی^{۲۴} (RBF) به عنوان تابع کرنل ماشین‌های بردار پشتیبان استفاده گردید که به صورت زیر بیان می‌شود (برزگر و همکاران ۲۰۱۶):

$$K(x, z) = \exp(-\gamma \|x - z\|), \quad \gamma > 0, \gamma = 1/(2\sigma^2)$$

[۴]

مدل هوش مصنوعی مرکب نظارت‌شده

مدل‌های هوش مصنوعی مرکب از گروهی از مدل‌های هوش مصنوعی تشکیل می‌شوند، که خروجی این مدل‌ها را برای رسیدن به یک نتیجه بهتر ترکیب می‌کنند. روش‌های مختلفی همچون روش متوسط‌گیری وزنی برای ترکیب مدل‌های هوش مصنوعی به کار گرفته شده‌اند (کخدایی ایلچی ۲۰۰۹، برزگر و اصغری مقدم ۲۰۱۶، برزگر و همکاران ۲۰۱۶c). در این مطالعه از یک شبکه عصبی مصنوعی غیرخطی برای ترکیب مدل‌های جداگانه هوش مصنوعی استفاده گردید. برای این منظور خروجی مدل‌های شبکه عصبی مصنوعی، عصبی-فازی و ماشین بردار پشتیبان که برای پیش‌بینی سطح آب دریاچه ارومیه به کار گرفته شدند، به عنوان ورودی مدل مرکب به شبکه عصبی مصنوعی وارد شدند. بنابراین،

یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کنند. این مدل از ساختاری پنج لایه‌ای با تعدادی متغیر ورودی، که هر ورودی دو یا چند تابع عضویت دارد، تشکیل می‌شود. ساختار این سیستم با داده‌های ورودی، نوع تابع عضویت ورودی و خروجی، قوانین و تعداد تابع عضویت انتخاب می‌گردد (پارسافر و معروفی، ۱۳۹۰). ساختار مدل استنتاج فازی عصبی تطبیقی به تفصیل در مطالعات متعددی (برزگر و همکاران ۲۰۱۶a,b,c) آورده شده است.

در مدل ANFIS از توابع عضویت ذوزنقه‌ای، مثلثی، سیگموئید، گوسی و زنگوله‌ای شکل به عنوان توابع ورودی و توابع ثابت^{۲۲} و خطی^{۲۳} به عنوان توابع خروجی استفاده می‌شود. در این تحقیق از تابع عضویت گوسی به عنوان تابع ورودی استفاده گردید. تابع گوسی دارای مزایای هموار و غیرصفر بودن است و نیز پارامترهای کمتری دارد. در این تحقیق برای آموزش مدل فازی-عصبی تطبیقی از دو الگوریتم پس‌انتشار خطا و الگوریتم ترکیبی که ترکیبی از دو روش کاهش گرادیان و کمینه مربعات است، استفاده گردید (برزگر و همکاران ۲۰۱۶a,b,d).

ماشین بردار پشتیبان

ماشین بردار پشتیبان یک تخمین‌گر رایج و قابل-اعتماد براساس یادگیری تحت نظارت است که تئوری و ایده اصلی آن توسط واپنیک (۱۹۹۵) ارائه گردید که تابع آن به صورت زیر بیان می‌شود (سالات و اوسوسکی ۲۰۰۴، شمشیربند و همکاران ۲۰۱۶، زجی و همکاران ۲۰۱۶):

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, z) + b_i$$

[۳]

24. Radial basis function

22. Constant

23. Linear

یک، دو و سه ماه آینده دریاچه ارومیه به ترتیب در گام-های ۴۶، ۸۷ و ۱۵۴ به دست آمدند. پس از آموزش و صحت‌سنجی مدل‌های شبکه عصبی به کار گرفته شده، داده‌های مرحله آزمایش برای پیش‌بینی مقادیر سطح آب دریاچه ارومیه برای مدل‌ها تعریف گردید. نتایج مدل‌های شبکه عصبی مصنوعی نشان می‌دهند که مدل‌سازی یک ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با ۰/۹۷۷۵، ۰/۱۱۰۲ متر و ۰/۰۹۷۲ متر و مدل-سازی سه ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با ۰/۸۸۶۹، ۰/۲۵۳۷ متر و ۰/۱۹۹۲ متر در مرحله آزمایش، به ترتیب بهترین و بدترین عملکرد را برای مدل‌های شبکه عصبی مصنوعی در پیش‌بینی سطح آب دریاچه دارند.

مدل‌های فازی-عصبی تطبیقی نیز با همان داده-های مربوط به مدل شبکه عصبی مصنوعی، آموزش و آزمایش گردیدند. در مدل‌های فازی-عصبی از الگوریتم ترکیبی که از روش‌های آموزش پس‌انتشار خطا و کمینه مربعات خطا بهره‌گیری می‌کند، برای بهینه‌سازی پارامترهای تابع عضویت گوسین و ضرایب معادلات خطی خروجی استفاده گردید. در این مدل‌ها تعداد گام و میزان خطا به ترتیب برابر با ۵۰۰ و صفر تنظیم گردید. در این مدل از روش‌های مختلفی از جمله روش افراز شبکه^{۲۸} و دسته‌بندی تفریقی^{۲۹} برای طبقه‌بندی داده‌ای استفاده می‌شود (برزگر و همکاران ۲۰۱۶a) که در این مطالعه از روش دسته‌بندی تفریقی استفاده شد. مهم‌ترین پارامتر در این روش تعیین شعاع دسته‌بندی می‌باشد که کنترل‌کننده تعداد دسته‌ها و قوانین فازی است. شعاع دسته‌بندی مدل‌ها با افزایش تدریجی از مقدار صفر تا یک بر اساس کمترین خطا به ترتیب برابر با ۰/۶۴، ۰/۶۵ و ۰/۶۲ برای مدل‌های پیش‌بینی سطح آب یک، دو و سه ماه آینده تعیین گردید. پس از پایان مرحله آموزش مدل‌ها، داده‌های مربوط به مرحله آزمایش برای مدل‌ها تعریف

مدل‌های مرکب به صورت شبکه‌های سه لایه MLP با الگوریتم آموزش لوبنبرگ-مارکوارت مورد استفاده قرار گرفتند که دارای سه نرون به صورت ورودی و یک نرون به صورت خروجی می‌باشند. توابع انتقال لایه‌های پنهان و خروجی به ترتیب TANSIG و PURELIN انتخاب شدند.

معیارهای ارزیابی عملکرد مدل‌ها

به منظور ارزیابی و مقایسه نتایج حاصل از مدل-های به کار برده شده در این تحقیق، از شاخص‌های آماری مانند ضریب تعیین^{۲۵} (R^2)، جذر میانگین مربعات خطا^{۲۶} ($RMSE$) و میانگین خطای مطلق^{۲۷} (MAE) استفاده گردید. روابط این معیارها به صورت زیر هستند.

$$R^2 = [\sum_{i=1}^N (F_i - \bar{F})(O_i - \bar{O})]^2 / [\sum_{i=1}^N (F_i - \bar{F})^2 (\sum_{i=1}^N (O_i - \bar{O})^2)]^{-1} \quad [5]$$

$$RMSE = [N^{-1} \sum_{i=1}^N (F_i - O_i)^2]^{0.5} \quad [6]$$

$$MAE = \frac{\sum |F_i - O_i|}{N} \quad [7]$$

در روابط فوق، O_i مقادیر مشاهداتی، \bar{O} میانگین مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده، \bar{F} میانگین مقادیر پیش‌بینی شده و N تعداد کل داده‌ها می‌باشند. هر چه مقادیر $RMSE$ و MAE به صفر و مقادیر R^2 به یک نزدیک باشند نشان‌دهنده نزدیک‌تر بودن مقادیر مشاهداتی و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.

نتایج و بحث

در مدل‌های شبکه عصبی مصنوعی بر اساس کمترین خطا، تعداد نرون‌های پنهان برای پیش‌بینی‌های یک، دو و سه ماه گام زمانی به ترتیب هفت، هشت و هفت تعیین شدند. کمترین خطای مدل‌ها پیش‌بینی سطح آب

28. Grid partitioning
29. Subtractive clustering (Sub-clustering)

25. Coefficient of determination
26. Root mean square error
27. Mean absolute error

۲ ارائه شده است. مقادیر بهینه C ، ϵ و γ به گونه‌ای تعیین شدند که نتایج به دست آمده دارای بیشترین مقدار ضریب تعیین و کمترین مقدار خطا باشند. نتایج مدل‌های بردار پشتیبان نشان می‌دهند که مدل‌سازی یک ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/981$ ، $0/0792$ متر و $0/0606$ متر و مدل‌سازی سه ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9205$ ، $0/1838$ متر و $0/1492$ متر در مرحله آزمایش، به ترتیب بهترین و بدترین عملکرد را برای مدل‌های بردار پشتیبان در پیش‌بینی سطح آب دریاچه دارند. به طور کلی، مقایسه عملکرد نشان داد که مدل بردار پشتیبان به مراتب نتایج بهتری نسبت به مدل‌های شبکه عصبی مصنوعی و سیستم عصبی- فازی تطبیقی در پیش‌بینی سطح آب دریاچه ارومیه دارند.

شد تا مقادیر پیش‌بینی شده محاسبه گردد. با توجه به معیارهای ارزیابی عملکرد مدل‌های فازی- عصبی می-توان گفت که مدل‌سازی یک ماه آینده سطح آب دریاچه با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9779$ ، $0/0926$ متر و $0/0704$ متر در مرحله آزمایش، بهترین عملکرد را دارد. حال آنکه، مدل‌سازی سه ماه آینده سطح آب دریاچه با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9178$ ، $0/2193$ متر و $0/1696$ متر در مرحله آزمایش، بدترین عملکرد را دارد.

مدل‌های بردار پشتیبان نیز با همان داده‌های مربوط به مدل شبکه عصبی مصنوعی و فازی- عصبی، آموزش و آزمایش گردیدند. مقادیر C ، ϵ و γ از مهم‌ترین پارامترهای تعیین‌کننده ساختار یک مدل ماشین بردار پشتیبان می‌باشد. مقادیر این پارامترها برای مدل‌سازی از طریق آزمون و خطا تعیین شدند که نتایج آن در جدول

جدول ۲- مقادیر بهینه پارامترهای C ، ϵ و γ در مدل‌های ماشین بردار پشتیبان.

مقادیر بهینه			مدل‌ها
γ	ϵ	C	
$0/01$	$0/015$	۱۱۰	سطح آب یک ماه آینده $h(t+1)$
$0/01$	$0/03$	۱۲۰	سطح آب دو ماه آینده $h(t+2)$
$0/01$	$0/06$	۱۵۰	سطح آب سه ماه آینده $h(t+3)$

نظارت شده نشان می‌دهند که مدل‌سازی یک ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9896$ ، $0/0547$ متر و $0/0421$ متر و مدل‌سازی سه ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9329$ ، $0/1322$ متر و $0/1034$ متر در مرحله آزمایش، به ترتیب بهترین و بدترین عملکرد را در پیش-بینی سطح آب دریاچه دارند. شکل ۳ مقایسه بین مقادیر سطح آب اندازه‌گیری شده و مدل‌سازی شده یک، دو و سه ماه آینده برای مدل‌های هوش مصنوعی مرکب نظارت شده در مرحله آزمایش را نشان می‌دهد. نتایج این پژوهش با نتایج پژوهش‌های واحد دوست و همکاران (۲۰۱۶)، شیری و همکاران (۲۰۱۶)، کاکاحاجی و همکاران

برای ایجاد مدل‌های هوش مصنوعی مرکب نظارت شده، تعداد نرون‌ها برای لایه پنهان مدل‌های مرکب پیش‌بینی سطح آب یک، دو و سه ماه آینده دریاچه ارومیه به ترتیب هشت، هشت و دوازده تعیین شدند. کمترین خطای مدل‌های مرکب پیش‌بینی سطح آب یک، دو و سه ماه آینده دریاچه ارومیه به ترتیب در گام‌های ۱۰۵، ۱۵۰ و ۴۱۶ به دست آمدند. نتایج حاصل از مدل‌سازی شبکه عصبی مصنوعی، سیستم استنتاج فازی- عصبی تطبیقی، ماشین بردار پشتیبان و هوش مصنوعی مرکب نظارت شده در مرحله آموزش و آزمایش به ترتیب در جدول‌های ۳ و ۴ نشان داده شده است. ارزیابی معیارهای عملکرد مدل‌های هوش مصنوعی مرکب

هوش مصنوعی در پیش‌بینی سطح آب دریاچه می‌باشد. اگر چه هیچ‌کدام از پژوهش‌ها، پیش‌بینی سطح آب به صورت ماهانه برای آینده را در نظر نگرفته‌اند.

(۲۰۱۳)، کیشی و همکاران (۲۰۱۵) که مدل‌های هوش مصنوعی را برای پیش‌بینی سطح آب دریاچه ارومیه به-کار برده‌اند همخوانی دارد و نشان‌گر کارایی مدل‌های

جدول ۳- نتایج حاصل از مدل‌سازی نوسانات سطح آب دریاچه ارومیه در مرحله آموزش.

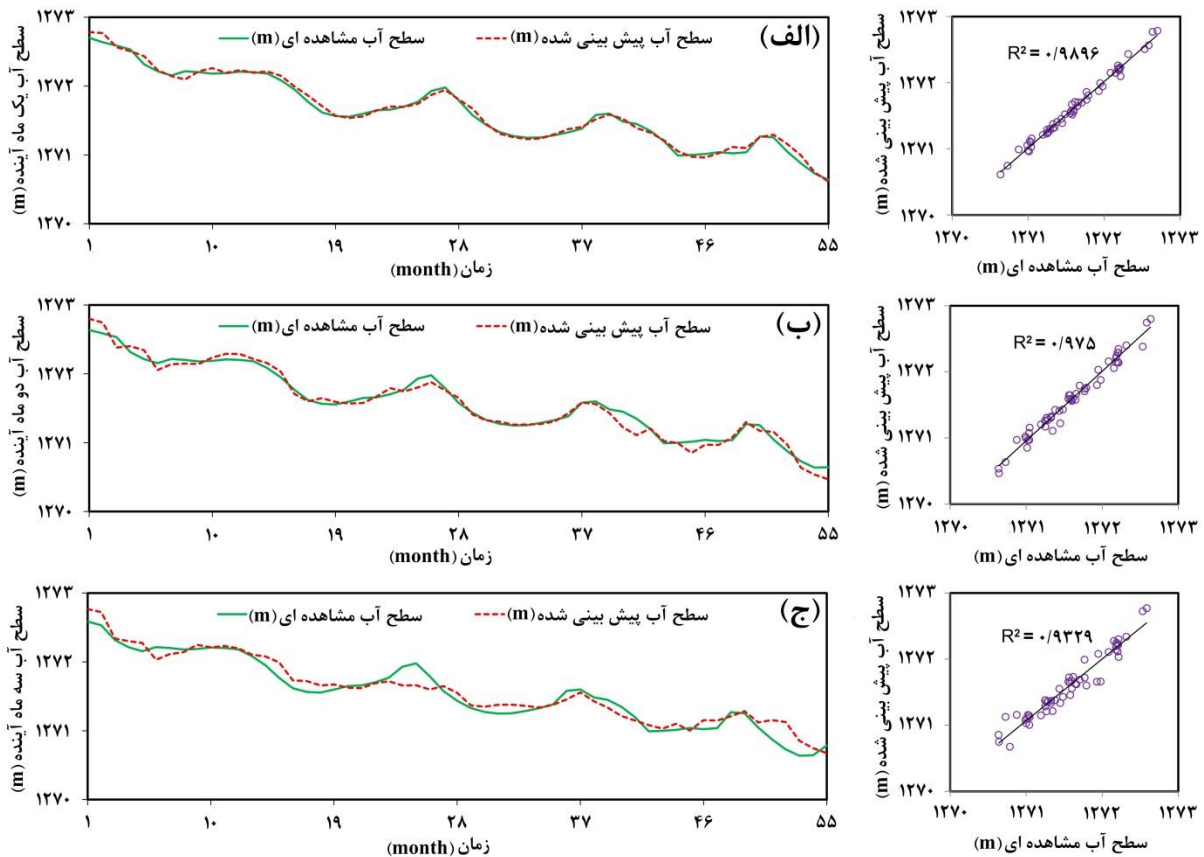
سطح آب سه ماه آینده			سطح آب دو ماه آینده			سطح آب یک ماه آینده			مدل
h (t+3)			h (t+2)			h (t+1)			
R^2	RMSE (m)	MAE (m)	R^2	RMSE (m)	MAE (m)	R^2	RMSE (m)	MAE (m)	
۰/۹۸۵۳	۰/۱۵۶۶	۰/۱۱۱۴	۰/۹۹۳۶	۰/۱۰۳۵	۰/۰۶۹۱	۰/۹۹۸۵	۰/۰۴۹۹	۰/۰۳۵۵	شبکه عصبی مصنوعی
۰/۹۸۳۰	۰/۱۶۸۷	۰/۱۲۳۵	۰/۹۹۰۴	۰/۱۲۶۷	۰/۰۸۹۰	۰/۹۹۶۹	۰/۰۷۲۲	۰/۰۴۷۹	فازی-عصبی
۰/۹۸۵۳	۰/۱۶۶۴	۰/۰۸۷۴	۰/۹۹۱۹	۰/۱۱۶۲	۰/۰۶۷۸	۰/۹۹۴۳	۰/۰۹۹۰	۰/۰۷۲۵	ماشین بردار پشتیبان
۰/۹۸۹۳	۰/۱۳۴۰	۰/۰۹۳۶	۰/۹۹۴۴	۰/۰۹۶۴	۰/۰۶۴۰	۰/۹۹۸۷	۰/۰۴۷۲	۰/۰۳۲۸	هوش مصنوعی مرکب نظارت-شده

جدول ۴- نتایج حاصل از مدل‌سازی نوسانات سطح آب دریاچه ارومیه در مرحله آزمایش.

سطح آب سه ماه آینده			سطح آب دو ماه آینده			سطح آب یک ماه آینده			مدل
h (t+3)			h (t+2)			h (t+1)			
R^2	RMSE (m)	MAE (m)	R^2	RMSE (m)	MAE (m)	R^2	RMSE (m)	MAE (m)	
۰/۸۸۶۹	۰/۲۵۳۷	۰/۱۹۹۲	۰/۹۴۴۶	۰/۱۶۶۱	۰/۰۶۹۱	۰/۹۷۷۵	۰/۱۱۰۲	۰/۰۹۷۲	شبکه عصبی مصنوعی
۰/۹۱۷۸	۰/۲۱۹۳	۰/۱۶۹۶	۰/۹۵۴۵	۰/۱۴۹۹	۰/۰۸۹۰	۰/۹۷۷۹	۰/۰۹۲۶	۰/۰۷۰۴	فازی-عصبی
۰/۹۲۰۵	۰/۱۸۳۸	۰/۱۴۹۲	۰/۹۶۷۲	۰/۱۳۴۹	۰/۰۶۷۸	۰/۹۸۱۰	۰/۰۷۹۲	۰/۰۶۰۶	ماشین بردار پشتیبان
۰/۹۳۲۹	۰/۱۳۲۲	۰/۱۰۳۴	۰/۹۷۵۰	۰/۰۸۹۶	۰/۰۶۴۰	۰/۹۸۹۶	۰/۰۵۴۷	۰/۰۴۲۱	هوش مصنوعی مرکب نظارت-شده

بایستی راهکارهای مدیریتی در جهت جلوگیری از کاهش سطح آب دریاچه صورت گیرد. از جمله راهکارهای مدیریتی می‌توان کاهش برداشت از آب‌های زیرزمینی حوضه آبریز دریاچه ارومیه به جهت ارتباط دریاچه و آبخوان‌های اطراف در بخش‌هایی از حوضه، افزایش و تقویت آب‌های ورودی سطحی به دریاچه و کاهش تبخیر اشاره کرد.

بر اساس دوره آماری ثبت شده، متوسط سطح آب دریاچه ارومیه در ماه جاری [h (t)] برای دوره آزمایش ۱۲۷۱/۶۷ متر می‌باشد. پس از مدل‌سازی بر اساس هوش مصنوعی مرکب نظارت‌شده، مقدار متوسط سطح آب برای یک و سه ماه آینده به ترتیب ۱۲۷۱/۶۵ و ۱۲۷۱/۵۹ متر پیش‌بینی می‌شود که نشان‌گر کاهش سطح آب در آینده با ادامه روند کنونی می‌باشد. بنابراین



شکل ۳- مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده (الف) یک، (ب) دو و (ج) سه ماه آینده سطح آب دریاچه ارومیه در مرحله آزمایش با استفاده از مدل هوش مصنوعی مرکب نظارت شده.

مصنوعی مرکب نظارت شده استفاده گردید. نتایج مدل-های مختلف نشان می‌دهند که مدل‌سازی یک ماه آینده سطح آب توسط مدل ماشین بردار پشتیبان با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با ۰/۰۷۹۲، ۰/۹۸۱ و ۰/۰۶۰۶ متر بهترین عملکرد را دارد حال آنکه مدل‌سازی سه ماه آینده سطح آب توسط مدل شبکه عصبی مصنوعی با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با ۰/۸۸۶۹، ۰/۲۵۳۷ متر و ۰/۱۹۹۲ در مرحله آزمایش بدترین عملکرد را دارد. به‌طور کلی مدل‌های ماشین بردار پشتیبان عملکرد بهتری نسبت به مدل‌های شبکه عصبی مصنوعی و عصبی-فازی نشان دادند. نتایج نشان داد مدل‌های هوش مصنوعی مرکب نظارت شده قادرند عملکرد مدل‌های منفرد هوش مصنوعی را بهبود دهند.

نتیجه‌گیری کلی

در این تحقیق از داده‌های سطح آب ماه جاری $[h(t)]$ و یازده ماه گذشته $[h(t-1), \dots, h(t-11)]$ دریاچه ارومیه برای پیش‌بینی سطح آب یک $[h(t+1)]$ و دو $[h(t+2)]$ و سه $[h(t+3)]$ ماه آینده دریاچه با به‌کارگیری مدل‌های شبکه عصبی مصنوعی، سیستم فازی-عصبی تطبیقی و ماشین بردار پشتیبان استفاده گردید و از معیارهای ضریب تعیین (R^2)، جذر میانگین مربعات خطا ($RMSE$) و میانگین مطلق خطا (MAE) برای ارزیابی عملکرد مدل‌ها بهره گرفته شد. در نهایت، به‌منظور ترکیب غیرخطی نتایج مدل‌های مختلف به کار گرفته شده و استفاده از توانایی مدل‌های مختلف به‌طور همزمان، از مدل هوش

به ترتیب برابر با MAE $0/9329$ ، $0/1322$ متر و $0/1034$ متر در مرحله آزمایش، به ترتیب بهترین و بدترین عملکرد را در پیش‌بینی سطح آب دریاچه دارند.

ارزیابی معیارهای عملکرد مدل‌های هوش مصنوعی مرکب نظارت شده نشان می‌دهند که مدل‌سازی یک ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و MAE به ترتیب برابر با $0/9896$ ، $0/0547$ متر و $0/0421$ متر و مدل‌سازی سه ماه آینده سطح آب با مقادیر R^2 ، $RMSE$ و

منابع مورد استفاده

- پارسافرن و معروفی م، ۱۳۹۰. برآورد دمای عمق‌های مختلف خاک از دمای هوا با به‌کارگیری روابط رگرسیونی، شبکه عصبی و شبکه عصبی-فازی (مطالعه موردی: منطقه کرمانشاه). نشریه دانش آب و خاک، جلد ۳، شماره ۲۱، صفحه‌های ۱۴۰ تا ۱۵۲.
- ندیری ع، طاهرخانی ز، صادقی ف، ۱۳۹۵. پیش‌بینی سطح آب زیرزمینی دشت بستان‌آباد با استفاده از ترکیب نظارت‌شده مدل‌های هوش مصنوعی. نشریه تحقیقات منابع آب ایران. تحت چاپ
- ندیری ع، اصغری مقدم ا، عبقری ه، کلانتری اسکویی ع، حسین‌پور ع و حبیب‌زاده ا، ۱۳۹۳. مدل منطق فازی در تخمین قابلیت انتقال آبخوان‌ها مطالعه موردی: دشت تسوج. نشریه دانش آب و خاک، جلد ۲۴، شماره ۱، صفحه‌های ۲۰۹ تا ۲۲۳.
- Barzegar R, Adamowski J, and Asghari Moghaddam A, 2016a. Application of wavelet-artificial intelligence hybrid models for water quality prediction: a case study in Aji-Chay River, Iran. *Stochastic Environmental Research and Risk Assessment* 30(7): 1797-1819.
- Barzegar R, and Asghari Moghaddam A, 2016. Combining the advantages of neural networks using the concept of committee machine in the groundwater salinity prediction. *Modeling Earth Systems and Environment* 2: 26.
- Barzegar R, Asghari Moghaddam A, Adamowski J, and Fijani E, 2016b. Comparison of machine learning models for predicting fluoride contamination in groundwater. *Stochastic Environmental Research and Risk Assessment* doi: 10.1007/s00477-016-1338-z.
- Barzegar R, Asghari Moghaddam A, and Baghban H, 2016c. A supervised committee machine artificial intelligent for improving DRASTIC method to assess groundwater contamination risk: a case study from Tabriz plain aquifer, Iran. *Stochastic Environmental Research and Risk Assessment* 30(3): 883-899
- Barzegar R, Sattarpour M, Nikudel MR, and Asghari Moghaddam A, 2016d. Comparative evaluation of artificial intelligence models for prediction of uniaxial compressive strength of travertine rocks, case study: Azarshahr area, NW Iran. *Modeling Earth Systems and Environment* 2:76.
- Ebtehaj I, Bonakdari H, Shamshirband S, and Mohammadi K, 2016. A combined support vector machine-wavelet transform model for prediction of sediment transport in sewer. *Flow Measurement and Instrumentation* 47: 19-27.
- Kadkhodaie-Ilkhchi A, Rezaee, M R, Rahimpour-Bonab H, and Chehrizi A, 2009. Petrophysical data prediction from seismic attributes using committee inference system. *Computers & Geosciences* 35: 2314-2330.
- Kakahaji H, Dehghan Banadaki H, Kakahaji A, and Kakahaji, A 2013. Prediction of Urmia Lake water-level fluctuations by using analytical, linear statistic and intelligent methods. *Water Resources Management* 27(13): 4469-4492.
- Karimi S, Shiri J, Kisi O, Makarynsky O, 2012. Forecasting water level fluctuations of Urmieh Lake using gene expression programming and adaptive neuro-fuzzy inference system. *International Journal of Ocean and Climate Systems* 3(2): 109-125.
- Khatami S, 2013. Nonlinear chaotic and trend analyses of water level at Urmia Lake, Iran. M.Sc. Thesis report: TVVR 13/5012, ISSN: 1101-9824, Lund University, Lund, Sweden.
- Kisi O, Shiri, J, Karimi S, Shamshirband S, Motamedi S, Petković D, and Hashim R, 2015. A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm. *Applied Mathematics and Computation* 270: 731-743.
- Naftaly U, Intrator N, and Horn D, 1997. Optimal ensemble averaging of neural networks. *Computation in Neural Systems* 8: 283-296.

- Salas JD, Deulleur JW, Yevjevich V, and Lane WL, 1980. Applied Modelling of Hydrologic Time Series. Water Resources Publ. Littleton, Colorado 484p.
- Salat R, Osowski S, 2004. Accurate fault location in the power transmission line using support vector machine approach. Power Systems IEEE Transactions on 19: 879–886.
- Sanikhani H, Kisi O, Kiafar H, and Ghavidel SZZ, 2015. Comparison of different data-driven approaches for modeling lake level fluctuations: The case of Manyas and Tuz Lakes (Turkey). Water Resources Management 29(5): 1557–1574.
- Şen Z, Kadioğlu M, and Batur, E, 2000. Stochastic modelling of the Van Lake monthly level fluctuations in Turkey. Theoretical and Applied Climatology 65(1–2): 99–110.
- Shamshirband S, Mohammadi K, Khorasanizadeh H, Yee PL, Lee M, Petkovic D, and Zalnezhad E, 2016. Estimating the diffuse solar radiation using a coupled support vector machine–wavelet transform model. Renewable & Sustainable Energy Reviews 56: 428–435.
- Shiri J, Shamshirband S, Kisi O, Karimi S, Bateni SM, Hosseini Nejad SH, and Hashemi A, 2016. Prediction of Water-Level in the Urmia Lake Using the Extreme Learning Machine Approach. Water Resources Management 30(14): 5217–5229.
- Talebizadeh M, and Moridnejad A, 2011. Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models. Expert Systems with Applications 38(4): 4126–4135.
- Vaheddoost B, Aksoy H, and Abghari H, 2016. Prediction of water level using monthly lagged data in Lake Urmia, Iran. Water Resources Management 30 (13): 4951–4967.
- Vapnik VN, 1995. The Nature of Statistical Learning Theory. Springer, New York, 314 p.
- Zaji AH, Bonakdari H, Khodashenas SR, and Shamshirband S, 2016. Firefly optimization algorithm effect on support vector regression prediction improvement of a modified labyrinth side weir's discharge coefficient. Applied Mathematics and Computation 274: 14–19